

Previsão de criação de valor corporativo em empresas do G20 a partir de informações contábeis: análise empregando algoritmos de inteligência artificial

Ewerton Alex Avelar
ewertonalexavelar@gmail.com
UFMG

José Roberto de Souza Francisco
jroberto@face.ufmg.br
UFMG

Ricardo Vinícius Dias Jordão
jordaoconsultor@yahoo.com.br
SKEMA

Vanessa Oliveira Otoni
vanessaootoni@gmail.com
UFMG

Andrea Miranda da Silva
andreams02@gmail.com
UFMG

Resumo: O estudo apresentado neste artigo visou prever o Market Value Added (MVA®) de empresas dos países do G20 com base em algoritmos de inteligência artificial (IA), a partir de variáveis contábeis. Para tanto, foram coletados, por meio da Plataforma Refinitiv® Eikon, dados de 16.452 companhias abertas dos países membros do G20 entre os anos de 2019 e 2022. Foram estimados modelos de previsão com base em regressão linear (RL) múltipla e em dois algoritmos de IA: random forest (RF) e redes neurais artificiais (RNA). Foram empregadas as seguintes técnicas para análise de dados: análise de regressão, estatística descritiva e teste de Mann-Whitney. Em geral, verificou-se que as variáveis contábeis foram relevantes para explicar o valor corporativo mesmo em períodos de crise (pandemia de Covid-19 e invasão da Rússia à Ucrânia). Todos os modelos foram considerados significantes e com alto poder explicativo do MVA®. Em alguns períodos, os modelos baseados em RNA apresentaram resultados estatisticamente superiores aos baseados em RL. Ademais, não se verificaram diferenças significantes entre os modelos estimados para os países desenvolvidos em relação aos emergentes. Diante do exposto, a pesquisa apresentada neste artigo contribui de forma relevante para a literatura sobre Contabilidade e Finanças sob diferentes aspectos:

(a) destacou-se a relevância das variáveis contábeis para previsão de valor corporativo, mesmo em períodos de crise; (b) evidenciou-se a importância de emprego de algoritmos de IA para análise desse fenômeno em estudos da área; e (c) os resultados foram corroborados considerando milhares de empresas provenientes dos países mais industrializados do mundo, tanto desenvolvidos quanto emergentes.

Palavras Chave: Market Value Added - Algoritmos de IA - Variáveis contábeis - G20 -

1. INTRODUÇÃO¹

A criação de valor corporativo é usualmente um tema de muita importância para acionistas, credores, investidores, analistas dentre outros *stakeholders*. No entanto, prever o valor de uma organização é um desafio na economia contemporânea, principalmente, em momentos de instabilidade político-econômica. O monitoramento da situação econômico-financeira e a previsão do desenvolvimento futuro das organizações são aspectos de bastante relevância nesse contexto.

Segundo Liapis *et al.* (2023), informações contábeis podem ser empregadas para a previsão de valor de uma empresa, incluindo o fluxo de caixa livre descontado e a utilização de indicadores econômico-financeiros provenientes das demonstrações contábeis da organização. Diversos trabalhos têm demonstrado o potencial de prever o valor de uma empresa com base em variáveis contábeis como endividamento, lucratividade e tamanho, tais como Aguiar *et al.* (2011), Mishra e Mohanty (2014), Marques *et al.* (2015) e Ross *et al.* (2015).

Destaca-se que, além de técnicas estatísticas convencionais, mais recentemente, algoritmos de inteligência artificial (IA) têm sido aplicados para mensurar o valor de empresas (FERREIRA *et al.*, 2021), inclusive, empregando variáveis contábeis (AVELAR *et al.*, 2022). Complementando, Cao *et al.* (2019) destacam que algoritmos de IA podem fornecer informações valiosas sobre estratégias e lucratividade e têm sido aplicados à previsão do valor das empresas. É importante destacar que a maior parte dos estudos de previsão de valor corporativo, foca nos preços das ações para mensurá-lo. Dentre as métricas de valor baseadas em preços de ações, destaca-se o *Market Value Added* (MVA®), de acordo com autores como Stewart (2005) e Vasconcelos e Callado (2019). Estes últimos autores definem o MVA® como uma medida da criação de valor corporativo, na qual o valor patrimonial (contábil) é descontado do valor de mercado da empresa.

Ressalta-se que medidas de valor que empreguem variáveis de mercado (como o MVA®) têm sido bastante afetadas nos últimos anos. Isso se deve principalmente a duas crises de grande magnitude que têm influenciado o valor das empresas ao redor do mundo: a pandemia de Covid-19 e a invasão russa à Ucrânia. A rápida expansão da pandemia em 2020 resultou em interrupção das atividades empresariais, diminuição da produção e dificuldades em atender às demandas do mercado. No entanto, alguns estudos identificaram empresas que conseguiram um desempenho superior durante o primeiro ano da pandemia, com base em características prévias refletidas em variáveis contábeis, tais como ressaltam Kaczmarek *et al.* (2021) e Ichsan *et al.* (2021). Já a invasão da Rússia à Ucrânia em 2022 também causou uma crise significativa e que afetou empresas ao redor do mundo, com resultados bastante heterogêneos sobre o valor das empresas (BOUGIAS *et al.*, 2022; ABBASSI *et al.*, 2023). Essas crises ressaltam a importância de se compreender e analisar o valor das empresas frente a eventos adversos de grande escala.

Diante do exposto, o estudo apresentado neste artigo visou responder ao seguinte problema de pesquisa: é possível prever o MVA® de empresas dos países do G20, com base em algoritmos de IA, empregando variáveis contábeis? Assim, a pesquisa objetivou prever o MVA® de empresas dos países do G20 com base em algoritmos de IA, a partir de variáveis contábeis. Para tanto, foram coletados dados de companhias abertas dos países membros do G20 entre os anos de 2019 e 2022. Nesse sentido, foram propostos e cumpridos os seguintes objetivos específicos: (i) identificar variáveis contábeis determinantes para a criação de valor corporativo das empresas ao longo do período analisado; (ii) verificar se essas variáveis

¹ Os autores agradecem ao apoio da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) no desenvolvimento desta pesquisa.

determinantes se mantêm relevantes para explicar o MVA® das empresas mesmo em períodos de crise; (iii) avaliar a capacidade de predição desse valor por parte de algoritmos de IA e de modelos de regressão; (iv) comparar os desempenhos dos modelos na previsão do valor das empresas entre países desenvolvidos e emergentes; e (v) discutir os resultados sob a perspectiva da literatura de Contabilidade e Finanças.

A pesquisa desenvolvida pode ser justificada sob várias perspectivas. Primeiramente, tem-se que o valor das empresas (e sua previsão) é um tema de muita importância para os *stakeholders*, considerando seus diferentes interesses na empresa. Ademais, destaca-se a relevância das variáveis contábeis para se analisar o valor e outros aspectos da sustentabilidade econômico-financeira das empresas, gerando informações quantitativas e qualitativas para os diversos tomadores de decisão. Além disso, ressalta-se que as crises recentes, pandemia de Covid-19 e a invasão russa à Ucrânia, apresentaram efeitos significantes sobre o valor das empresas ao redor do mundo, mas com alta heterogeneidade. Salienta-se, ainda, a amplitude do estudo, que enfocou milhares de empresas atuantes nos países com maior importância econômica do mundo, tanto desenvolvidos quanto emergentes. Por fim, aborda-se o emprego recente de algoritmos de IA, que têm sido bastante usados em estudos devido a sua forma de predição de maneira complexa e dinâmica do valor das empresas, e que ainda apresentam um grande potencial de aplicações em Contabilidade e Finanças.

Este artigo está dividido em cinco seções, contando com esta Introdução. Na seção 2, apresenta-se a revisão da literatura e são desenvolvidas as hipóteses do estudo. Em seguida, os procedimentos metodológicos são descritos na seção 3. Posteriormente, os resultados são apresentados e discutidos (seção 4). Por fim, as conclusões são destacadas na seção 5, seguidas das referências bibliográficas.

2. REVISÃO DA LITERATURA

Gavurova *et al.* (2022) destacam que, na economia contemporânea, bastante complexa, torna-se usualmente difícil manter a estabilidade econômico-financeira das empresas. Ainda conforme os referidos autores, isso faz com que o monitoramento da situação econômico-financeira dessas organizações e a previsão sobre seu desenvolvimento futuro se torne um tópico muito relevante.

Dentre os aspectos normalmente considerados essenciais para a sustentabilidade empresarial está a criação de valor corporativo. Liapis *et al.* (2023) afirmam que compreender o valor de uma empresa é crucial para diversos *stakeholders*, tais como acionistas, credores, investidores e analistas. Salienta-se que o valor de uma empresa pode ser mensurado por meio dos preços de suas ações negociadas no mercado de capitais conforme Ananthakumar e Sarkar (2017). Dentre as diferentes formas de mensurar o valor da empresa com base nos preços de suas ações no mercado, pode ser destacado o MVA®. Tal métrica é definida por Stewart (2005, p.615) como:

A diferença entre o valor de mercado de uma empresa e seu capital empregado, o MVA® é a medida do valor que uma empresa criou em excesso, sobre recursos já comprometidos com o empreendimento. Em tese, o MVA® representa o valor presente líquido de todos os projetos de investimento de capital passados e projetados.

Devido à importância de se prever o valor de uma empresa para os *stakeholders*, diversos estudos têm destacado o potencial de se realizar essa previsão com base em variáveis econômico-financeiros provenientes das demonstrações contábeis tais como Belhaj e Mamoghli (2019), Husain *et al.* (2020), Jallow *et al.* (2022) e Liapis *et al.* (2023). Nesse sentido, diferentes variáveis contábeis podem ser empregadas para prever o valor das empresas no mercado, sendo que três se destacam: endividamento, lucratividade e tamanho (AGUIAR *et al.*,

2011; MISHRA & MOHANTY, 2014; MARQUES *et al.*, 2015; ROSS *et al.*, 2015). Essas variáveis podem ser entendidas como variáveis determinantes de valor (Quadro 1). Diante do exposto, foi desenvolvida a Hipótese 1 (H1) do estudo:

H1: *As variáveis contábeis são significantes para explicar o MVA® das empresas independentemente do país de origem.*

Quadro 1: Variáveis contábeis determinantes de valor

Variável	Justificativa
Endividamento	Os benefícios fiscais da dívida tendem a auxiliar na criação de valor ao reduzir o custo ponderado de capital; e altos níveis de endividamento aumentam o risco da empresa e seus custos de falência.
Lucratividade	Evidencia o aumento dos benefícios econômicos e está estreitamente relacionada à criação de valor corporativo.
Tamanho	Companhias maiores podem gerar valor devido ao seu volume de ativos, reputação e capacidade de negociar melhores condições.

Fonte: elaborado pelos autores.

Recentemente, o valor de mercado das empresas ao redor do mundo foi afetado por duas crises: Pandemia de Covid-19 e Invasão da Rússia à Ucrânia. No que se refere à pandemia, cuja rápida expansão mundial ocorreu no primeiro semestre de 2020, muitas empresas precisaram interromper suas atividades, tendo diminuição na produção e no atendimento das demandas do mercado, com governos tendo que ajustar suas políticas para ajudar a população e as empresas (MULYANINGSIH *et al.*, 2021). Estudos como os de Kaczmarek *et al.* (2021), Ichsan *et al.* (2021) e Mulyaningsih *et al.* (2021) evidenciaram efeitos diversos negativos da pandemia de Covid-19 sobre o desempenho e o valor de empresas ao redor do mundo, sendo que alguns setores foram mais impactados que outros. Ademais, os referidos estudos também evidenciaram que algumas empresas conseguiram um desempenho superior às demais durante o primeiro ano da pandemia, a partir de características prévias refletidas em variáveis contábeis.

No que tange à invasão russa à Ucrânia, ocorrida em fevereiro de 2022, esta também gerou uma crise que afetou de forma significativa as empresas ao redor do mundo. Bougias *et al.* (2022) destacam que empresas que tiveram maior exposição à Rússia experimentaram retornos de ativos e ações mais baixos no início da guerra, e, por ventura, níveis altos de risco de crédito. Dessa forma, houve um impacto estatisticamente significativo nos retornos de ações e dívidas e a probabilidade de inadimplência. As empresas com ativos mais voláteis experienciaram retornos de dívida mais baixo e mudanças na inadimplência mais alta. Ainda segundo os mesmos autores, fatores como tamanho e liquidez, analisado nas empresas estudadas durante o período de invasão da Rússia à Ucrânia, não tiveram poder em explicar os retornos dos títulos. Já Abbassi *et al.* (2023) verificaram que o país e o setor de atuação das empresas, assim como outras variáveis contábeis, também foram relevantes para explicar o comportamento do valor durante a invasão.

As referidas crises afetaram significativamente, inclusive, as empresas do grupo de países mais industrializados do mundo, o G20. Este foi fundado em 1999 após a crise financeira asiática como um fórum para os Ministros das Finanças e Presidentes dos Bancos Centrais discutirem questões econômico e financeiras globais. Ele é formado pela União Europeia e por 19 países, quais sejam: Argentina, Austrália, Brasil, Canadá, China, França, Alemanha, Índia, Indonésia, Itália, Japão, República da Coreia, México, Rússia, Arábia Saudita, África do Sul, Turquia, Reino Unido e Estados Unidos da América (EUA). Estes países representam aproximadamente 85% do produto interno bruto (PIB) global, mais de 75% do comércio mundial e cerca de dois terços da população (G20, 2023). Nesse sentido, foi proposta a Hipótese 2 (H2):

H2: *As variáveis contábeis são significantes para explicar o MVA® das empresas, mesmo em períodos de crise (pandemia de Covid-19 e a invasão da Rússia à Ucrânia).*

Destaca-se que, devido à relevância do valor das empresas ao longo dos últimos anos para os agentes econômicos, muitos estudos têm se focado na potencialidade de ferramentas como a IA com a finalidade de predição, obtendo desempenhos acima da média, como exposto em Cao *et al.* (2019), Qian e Rasheed (2007) e Shynkevich *et al.* (2017). Salienta-se que dois dos principais algoritmos usados para realizar essa previsão dos valores das empresas, segundo Avelar *et al.* (2022), são: Redes Neurais Artificiais (RNA) e *Random Forest* (RF).

As RNA são baseadas na maneira que se acredita que o cérebro humano funciona. Dessa forma, diversos valores são dispostos e cada receptor adquire um valor diferente, operando e gerando informações, que são analisadas e retiradas. Este modelo de rede de neurônios pode estar disposto em uma ou mais camadas diferentes, que suportam permanecer ligadas à camada anterior de neurônios de forma completa, parcial ou apenas local (FACELI *et al.*, 2021). As RNA possuem como uma qualidade importante a capacidade de aprender com exemplos retratados na forma de parâmetros, que são adaptados conforme tenha ligação com a interatividade com o ambiente externo e a regulação do aprendizado. Esta regulação abrange a definição de aprendizado pré-estabelecido no desenvolvimento do modelo (BRAGA *et al.*, 2007).

Já Sadorsky (2021) define o algoritmo de RF como a combinação de diferentes árvores de decisões, que tratam dados não paramétricos por meio de um treinamento supervisionado. Dessa forma, segundo os referidos autores, esse algoritmo manuseia uma base de dados existente e cria distintas árvores, que visam buscar a média dos resultados gerados. Conforme James *et al.* (2013), a RF tem como um de seus atributos a competência de ignorar alguns fatores de previsão, permitindo que o modelo faça a exclusão das possibilidades, o que racionaliza a capacidade utilizada. Diante do que foi apresentado, desenvolve-se a Hipótese 3 (H3):

H3: *O desempenho dos algoritmos de IA para previsão do MVA® é superior ao de técnicas estatísticas tradicionais.*

Destaca-se que, independentemente do modelo empregado para previsão em finanças (estatísticos ou baseados em IA), a qualidade dos dados como *inputs* e a eficiência na precificação das informações pelos agentes econômicos devem ser consideradas. Baseando-se na Hipótese do Mercado Eficiente (HME) destacada por Fama (1970), há expectativa de que as informações referentes às decisões financeiras tomadas nas empresas sejam precificadas pelo mercado. Essa hipótese sugere que os preços das ações nos mercados financeiros refletem totalmente as informações disponíveis e relevantes, não sendo possível, assim, a obtenção de retornos anormais (NAZLIOGLU *et al.*, 2023).

Além disso, Borges (2010) destaca que a eficiência de um mercado varia ao longo do tempo e de acordo com contexto econômico, político e social de determinado país, sendo que Sánchez-Granero *et al.* (2020) e Nazlioglu *et al.* (2023) ressaltam diferenças entre países desenvolvidos e emergentes. Para aqueles primeiros autores, a eficiência de mercado tende a ser maior em países desenvolvidos em relação aos emergentes, o que implica maiores oportunidades de lucros (considerando maiores níveis de risco) para investidores nestes últimos.

Uma vez que as informações provenientes das demonstrações contábeis divulgadas periodicamente pelas organizações são relevantes informações públicas precificadas pelo mercado, os diferentes *stakeholders* (analistas, credores, gestores etc.) têm interesse em averiguar a qualidade das mesmas em mercados desenvolvidos e emergentes para o

desenvolvimento de modelos preditivos (AL ANI, 2021). Nesse contexto, Chaney *et al.* (2011) destacam que a qualidade da informação contábil divulgada pelas empresas pode ser mensurada de diversas formas (persistência dos lucros, *value relevance*, gerenciamento de resultados etc.).

Tal como no caso da eficiência de mercado, a classificação de países em emergentes e desenvolvidos é considerado um preditor importante para a qualidade da informação contábil divulgada pelas empresas. De forma geral, em países desenvolvidos, são esperadas informações com maior qualidade, devido a um melhor ambiente institucional, com segurança jurídica e proteção aos acionistas minoritários, por exemplo, de acordo com Viana Jr. *et al.* (2023). Al-Enzy *et al.* (2023) ressaltam que, em alguns países emergentes, nem mesmo a convergência às normas internacionais de Contabilidade (*International Financial Reporting Standards – IFRS*) melhorou a qualidade da informação contábil.

Diante do exposto e considerando que a maior parte dos estudos historicamente usa variáveis baseadas em informações contábeis para explicar o valor corporativo, tais como Belhaj e Mamoghli (2019), Husain *et al.* (2020), Jallow *et al.* (2022) e Liapis *et al.* (2023), foi proposta a Hipótese 4 (H4):

H4: *Técnicas estatísticas tradicionais e algoritmos de IA usados para explicar o MVA® apresentam desempenhos preditivos superiores para os países desenvolvidos em relação aos países emergentes.*

3. METODOLOGIA

A pesquisa cujos resultados são apresentados neste artigo pode ser categorizada como quantitativa e descritiva. A população do estudo se referiu às companhias abertas dos países membros do G20, principal fórum de cooperação econômica internacional (G20, 2023). A composição da amostra consistiu em companhias abertas cujos dados estavam atualizados e disponíveis na Plataforma Refinitiv® Eikon no período de 2019 a 2022, ou seja, incluindo o último período pré-crise (2019) e de crises enfrentados pelas empresas: a Pandemia da Covid-19 e a invasão russa à Ucrânia.

Salienta-se que foram selecionadas empresas com patrimônio líquido positivo em todos os anos, para evitar a análise de organizações que já apresentavam problemas econômico-financeiros prévios. Ademais, foram selecionadas empresas que apresentaram MVA® positivo ao longo de todo o período, para compreender melhor os direcionadores de manutenção de valor. Após esses filtros, a amostra foi composta por 16.452 empresas.

Foram coletados dados das demonstrações contábeis necessários para calcular as variáveis determinantes de valor. Salienta-se que, além das variáveis contábeis clássicas, também se incluiu o risco, devido à sua intrínseca relação com o valor corporativo, conforme salientam Marques *et al.* (2015) e Ross *et al.* (2015). A operacionalização das variáveis é apresentada no Quadro 2. Destaca-se, ainda, que a seleção da maneira de operacionalizar as variáveis foi feita de forma a minimizar o número de dados ausentes, sendo que observações com tais dados foram retiradas da amostra.

Quadro 2: Operacionalização das variáveis

Variável	Operacionalização	Sinal esperado
MVA®	$\ln(\text{Valor de Mercado} - \text{Patrimônio Líquido})$	Não se aplica
END	$(\text{Passivo Circulante} + \text{Passivo não Circulante}) \div \text{Ativo Total Médio}$	-
LUC	$\text{EBIT} \div \text{Ativo Total Médio}$	+
RIS	$\text{Cov}(\text{Retorno}_{\text{Ativo}}, \text{Retorno}_{\text{mercado}}) \div \text{Var}(\text{Retorno}_{\text{mercado}})$	-
TAM	$\ln(\text{Ativo Total})$	+

Fonte: Elaborado pelos autores

Inicialmente, essas variáveis foram empregadas para desenvolver modelos de regressão lineares (RL) múltiplas anuais para as empresas de cada país, seguindo as orientações de Gujarati e Porter (2011). Conforme os referidos autores, foram realizados os seguintes testes de pressupostos do modelo: Breusch-Pagan-Godfrey (homoscedasticidade), Durbin-Watson (autocorrelação) e Shapiro Wilk (normalidade). O modelo base estimado é apresentado na Equação 1, na qual o termo t representa o ano e o termo ε , o erro.

$$MVA_t = \beta_0 + \beta_1 \times TAM_t + \beta_2 \times END_t + \beta_3 \times LUC_t + \beta_4 \times RIS_t + \varepsilon \quad (1)$$

Todos os algoritmos de IA foram executados para fins de regressão, com o propósito de prever o MVA® das empresas, empregando as mesmas variáveis apresentadas no Quadro 2. Para o treinamento dos modelos, foram usados 80% dos dados da amostra anualmente. Para estimar o desempenho desses modelos, optou-se pelo cálculo do *Mean Absolute Percentage Error* (MAPE) (Equação 2) e do *Root Mean Squared Error* (RMSE) (Equação 3). Ambas as medidas são usualmente empregadas para avaliar o erro de modelos para fins de regressão, calculados a partir dos dados de teste (20% remanescente da amostra). Ressalta-se que, por se tratarem de métricas de erro, quanto menor o valor, melhor o desempenho do modelo.

$$MAPE = \frac{1}{n} \sum_{i=1}^n (|valor_real| - |valor_predito| \div |valor_real|) \quad (2)$$

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (|valor_real| - |valor_predito|)^2} \quad (3)$$

Salienta-se que alguns parâmetros específicos foram ajustados para os algoritmos. No caso do RF, foi dada a possibilidade de o próprio algoritmo selecionar o número de árvores (entre 1 e 50) que aprimorasse o desempenho. Por sua vez, no caso das RNA, foi usada uma abordagem empírica para definir a melhor arquitetura da rede (número de camadas ocultas e de neurônios por camada), que otimizasse o desempenho. Considerou-se o uso de até duas camadas ocultas, de forma a possibilitar o aprendizado profundo, tal como evidenciado por Faceli *et al.* (2021), com até quatro neurônios por camada. Considerou-se, ainda, o número máximo de etapas para convergência de 10 milhões, sendo que, quando a convergência não era obtida com base nesse limite, o modelo foi estimado considerando apenas uma camada oculta de neurônios. Em ambos os algoritmos, foi estimado um modelo para cada país anualmente.

Foram empregadas as seguintes técnicas para análise de dados: análise de regressão, estatística descritiva e teste de Mann-Whitney. A análise de regressão, já apresentada, foi empregada para se identificar a influência das variáveis determinantes sobre o valor das empresas dos países do G20 em todos os períodos estudados (2019 a 2022). Por sua vez, a estatística descritiva foi empregada para descrever melhor os resultados gerais de desempenho da pesquisa. Por fim, teste de Mann-Whitney foi empregado para avaliar o desempenho dos diferentes modelos estimados entre si. O nível de significância adotada nos testes referentes à regressão foi de 5%, enquanto no caso do teste de Mann-Whitney foi de 10,0% (devido ao fato de o teste não paramétrico contar com um menor número de observações). Todos os dados foram tratados e analisados a partir do MS-Excel e do R. Por fim, o Quadro 3 apresenta a relação entre objetivos específicos, hipóteses e técnicas para a análise dos dados.

Quadro 3: Relação entre objetivos específicos, hipóteses e técnicas para a análise dos dados.

Objetivo específico	Hipótese	Técnica(s) de análise
Identificar as variáveis determinantes para a criação de valor corporativo das empresas ao longo do período analisado.	H1	Análise de regressão
Verificar se essas variáveis determinantes se mantêm relevantes para explicar o MVA® das empresas mesmo em períodos de crise.	H2	Análise de regressão
Avaliar a capacidade de predição desse valor por parte de algoritmos de IA e de modelos de regressão.	H3	Estatística descritiva; e teste de Mann-Whitney
Comparar os desempenhos dos modelos na previsão do valor das empresas entre países desenvolvidos e emergentes	H4	Estatística descritiva; e teste de Mann-Whitney
Discutir os resultados sob a perspectiva da literatura de Contabilidade e Finanças.	-	Não se aplica

Fonte: elaborado pelos autores.

4. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

4.1. VARIÁVEIS CONTÁBEIS COMO DETERMINANTES DE MVA®

Nesta subseção, apresentam-se os resultados dos modelos de RL estimados de forma a identificar as variáveis determinantes para a criação de valor corporativo das empresas ao longo do período analisado, assim como para verificar se essas variáveis determinantes se mantêm relevantes para explicar esse valor mesmo em períodos de crise. Destaca-se que, em caso de heterocedasticidade, os coeficientes foram estimados empregando os erros-padrão robustos de White. Ademais, mesmo quando os resíduos não apresentaram normalidade em sua distribuição (mensurado pelo teste de Shapiro Wilk), o número de observações foi o suficiente para pressupor a normalidade assintótica de acordo com Gujarati e Porter (2011).

As tabelas 1 e 2 apresentam os resultados obtidos em todos os modelos por país anualmente. Ademais, o alto valor do coeficiente de determinação (R^2), cuja média foi de 76,9%, indica que os modelos estimados conseguiram explicar a maior parte da variabilidade do valor das empresas medido pelo MVA®. Esses resultados ratificam a capacidade explicativa das variáveis selecionadas sobre o fenômeno, corroborando-se H1, em consonância com estudos como os de Aguiar *et al.* (2011), Mishra e Mohanty (2014) e Marques *et al.* (2015).

Ao se analisar os resultados das tabelas, destaca-se que a variável TAM foi significativa em praticamente todos os modelos em todos os anos. Houve uma única exceção: o modelo estimado para a Coreia do Sul em 2022. Além disso, o coeficiente positivo e significativo a menos de 1,0% nos modelos ao longo de todo o período reforça a consistência dessa variável em explicar o valor das empresas. Por sua vez, a variável LUC também se apresentou significativa em diversos anos para as empresas de vários países. Em geral, seu coeficiente foi positivo na maior parte desses modelos estimados, indicando sua importância na criação de valor. Porém, em alguns modelos estimados, o coeficiente obtido foi negativo, demonstrando sua influência na redução do MVA®. Esse resultado negativo foi bastante consistente para as empresas australianas (em todos os anos) e canadenses (exceto em 2020). Outros modelos apresentaram resultados semelhantes apenas em 2022: os estimados para o Brasil e a Coreia do Sul.

Já no que se refere à variável END, seu coeficiente foi significativo e negativo para a maior parte dos modelos estimados em todos os anos. Tal resultado indica a consistência dessa variável em reduzir o MVA® das empresas estudadas. Por fim, no que se refere à variável RIS, verificam-se coeficientes significativos tanto positivos quanto negativos, dependendo do país e do ano para os quais os modelos foram estimados. Em geral, observa-se a relevância das variáveis em explicar o MVA® das empresas do G20. Todas as variáveis contábeis selecionadas foram significativas em quase todos os modelos, ratificando sua importância para previsão de valor corporativo mesmo em períodos de crise. Dessa forma, corrobora-se H2.

Tabela 1: Modelos de RL estimados para os anos de 2019 e 2020

Ano	2019						Interc.	LUC	TAM
	País	Interc.	LUC	TAM	END	RIS			
África do Sul	3,9509*	5,8951**	0,7430**	-0,4097	0,6082	0,7800	3,7323*	6,6476**	0,7543**
Alemanha	2,5680**	0,741	0,9012**	-1,4111**	-0,125	0,8299	2,4823**	0,2791	0,9062**
Arábia Saudita	3,6891**	0,8266	0,8480**	-1,1364*	-0,1825	0,7021	6,5636**	1,4419	0,7078**
Argentina	0,4009	1,7907	0,9591**	-0,6639	-1,1125	0,8274	1,1603	1,3824	0,9080**
Austrália	1,4973	-0,0542*	0,9185**	-0,795	0,0892	0,7591	1,9608	-1,1582*	0,9169**
Brasil	1,9136	0,6361	0,9433**	-1,8374**	-0,0352	0,6846	2,4003*	0,8306	0,9099**
Canadá	1,5786**	-0,8649**	0,9155**	-0,7942**	-0,0527	0,8438	3,3004**	-0,2634	0,8564**
China	6,1639**	2,5240**	0,7210**	-1,7566**	0,2907**	0,6083	6,0296**	3,7006**	0,7223**
Coréia do Sul	5,1339**	0,1349	0,7420**	-1,7085**	0,0484	0,6585	6,0061**	0,4466	0,7059**
EUA	2,3446**	0,0578	0,9407**	-2,5877**	0,1041**	0,7822	2,6743**	0,1306	0,9495**
França	2,7388**	0,8364	0,9030**	-2,9763**	0,4109**	0,8539	3,2514**	-1,104	0,8914**
Índia	1,0585**	5,5067**	0,9652**	-1,3412**	-0,2951**	0,7511	1,4509**	5,3525**	0,9601**
Indonésia	1,9613**	4,6499**	0,9057**	-1,6854**	-0,0988	0,7147	2,1909**	3,5619**	0,8901**
Itália	3,5421**	10,6792*	0,8046**	-0,8782	-0,3417	0,789	3,8556**	7,9437	0,8305**
Japão	3,9449**	2,5917**	0,8174**	-2,2211**	0,0869*	0,7787	4,0358**	1,6251**	0,8109**
México	-0,7474	6,1809**	1,0203**	-1,4150**	-0,0467	0,8462	-0,8228	5,7148**	1,0235**
Reino Unido	3,0253**	0,9942**	0,8488**	-0,8460**	0,2152*	0,8055	3,0837**	0,5219	0,8679**
Rússia	-1,4183	10,6714**	0,9856**	-0,7843	0,0332	0,9518	-1,0240	7,7264**	1,0170**
Turquia	4,6282**	3,4888**	0,7446**	-0,7579**	0,1347	0,7326	8,0226**	2,2818**	0,6157**

Nota: * coeficiente significante a menos de 5,0%; ** coeficiente significante a menos de 1,0%

Fonte: elaborada pelos autores.

Tabela 2: Modelos de RL estimados para os anos de 2021 e 2022

País	2021						2022		
	Interc.	LUC	TAM	END	RIS	R ²	Interc.	LUC	TAM
África do Sul	3,5601*	3,2095*	0,7743**	-0,3414	0,1433	0,7515	2,4446	4,2057*	0,8468**
Alemanha	3,0218**	0,9299*	0,8692**	-1,1532**	0,0449	0,8268	3,1810**	1,5364**	0,8376**
Arábia Saudita	6,2892**	-0,4331	0,7574**	-1,6602**	-0,2111	0,6525	3,7034**	2,0576*	0,8580**
Argentina	1,0767	1,9832	0,9249**	-2,3880**	-0,3404	0,7594	1,5938	1,4644	0,9423**
Austrália	1,7728	-1,1135*	0,9381**	-1,6734**	-0,0608	0,7549	1,3968	-1,0331**	0,9416**
Brasil	2,2667*	-0,4272	0,9365**	-2,4286**	-0,1962	0,7257	1,1054	-0,4051**	1,0049**
Canadá	1,8807**	-0,8076**	0,9303**	-1,4282**	-0,1007*	0,8488	1,3199**	-0,4454**	0,9436**
China	6,6794**	2,6274**	0,7008**	-1,6584**	0,3905**	0,5903	6,3077**	1,8518*	0,6959**
Coréia do Sul	6,0285**	-0,0142	0,7126**	-1,5574**	-0,0614	0,6355	5,1776**	-0,6999**	0,741
EUA	1,9551**	0,3442	0,9721**	-2,7714**	-0,0053	0,7632	1,1881**	0,3014**	0,9928**
França	3,2507**	-0,2888	0,8821**	-2,1663**	-0,1571	0,775	3,0945**	0,814	0,8830**
Índia	2,0314**	4,3644**	0,9344**	-1,1784**	-0,3198**	0,7610	1,4380**	4,5310**	0,9464**
Indonésia	3,0631**	2,5453**	0,8488**	-1,1917**	-0,1517*	0,69	2,6430**	2,5087**	0,8622**
Itália	4,6834**	3,0635	0,7969**	-1,2186	-0,5702*	0,7288	3,2885**	2,5291	0,8756**
Japão	3,2740**	1,4748**	0,8459**	-2,6041**	0,2925	0,7864	2,7541**	1,0900*	0,8614**
México	-2,6236	6,3212**	1,1050**	-1,3630**	-0,1337	0,8294	-3,0684*	6,3273**	1,1210**
Reino Unido	3,2726**	0,9730**	0,8610**	-0,8104**	-0,2808**	0,8097	2,2918**	1,1291**	0,8997**
Rússia	-0,3649	5,2783**	1,0041**	-1,4452**	-0,6889	0,9472	0,6596	4,4022**	0,9480**
Turquia	7,0170**	3,9380**	0,6068**	-0,415	0,1796	0,6692	5,5046**	2,6085**	0,6988**

Nota: * coeficiente significante a menos de 5,0%; ** coeficiente significante a menos de 1,0%

Fonte: elaborada pelos autores.

4.2. ALGORITMOS DE IA PARA PREVISÃO DE MVA®

Nesta subseção, apresenta a avaliação da capacidade de predição do MVA® por parte de algoritmos de IA e dos modelos de RL. Destacam-se as estatísticas de desempenho dos modelos estimados na Tabela 3. É importante evidenciar que, como são medidas de erro, os valores mais baixos indicam um melhor desempenho dos modelos. Observa-se que, consistentemente, os modelos estimados segundo os algoritmos apresentaram resultados medianos superiores àqueles estimados com base em RL, pois os erros, calculados pelas medidas MAPE e RMSE, foram inferiores, nos quatro anos analisados, nos algoritmos de IA empregados na pesquisa em relação àquela técnica estatística tradicional. Complementarmente, nas figuras 1a e 1b, ressaltam-se, respectivamente, as medianas do MAPE e do RMSE dos modelos baseados em RL e em algoritmos de IA ao longo dos anos.

Tabela 3: Estatísticas de desempenho dos modelos estimados

Modelos	Medida/ Ano	MAPE/ 2019	RMSE/ 2019	MAPE/ 2020	RMSE/ 2020	MAPE/ 2021	RMSE/ 2021	MAPE/ 2022	RMSE/ 2022
Modelos baseados em RL	Média	0,0425	1,1293	0,0432	1,1209	0,0412	1,0956	0,0375	0,9580
	DP	0,0189	0,5159	0,0166	0,4541	0,0176	0,4819	0,0147	0,4311
	CV	0,4434	0,4568	0,3851	0,4051	0,4270	0,4399	0,3923	0,4501
	Mediana	0,0376	0,9495	0,0413	1,0595	0,0397	1,0062	0,0370	0,8891
	Máximo	0,0995	2,7547	0,1047	2,7988	0,1085	2,8573	0,0891	2,4945
	Mínimo	0,0205	0,5905	0,0223	0,5467	0,0226	0,5489	0,0176	0,4253
Modelos baseados em RF	Média	0,0389	1,0306	0,0423	1,0944	0,0406	1,0589	0,0391	0,9959
	DP	0,0149	0,4154	0,0155	0,3982	0,0164	0,4107	0,0140	0,3577
	CV	0,3831	0,4031	0,3656	0,3638	0,4041	0,3879	0,3578	0,3592
	Mediana	0,0358	0,9756	0,0404	0,9984	0,0361	0,9459	0,0368	0,9106
	Máximo	0,0903	2,5195	0,1001	2,5778	0,1026	2,6319	0,0806	2,1518
	Mínimo	0,0197	0,5449	0,0267	0,7012	0,0268	0,6922	0,0228	0,5754
Modelos baseados em RNA	Média	0,0355	0,9383	0,0386	1,0020	0,0387	0,9993	0,0355	0,9070
	DP	0,0149	0,4490	0,0159	0,4339	0,0169	0,4532	0,0136	0,3549
	CV	0,4195	0,4785	0,4134	0,4330	0,4355	0,4535	0,3821	0,3913
	Mediana	0,0316	0,7982	0,0336	0,8544	0,0335	0,8738	0,0324	0,8146
	Máximo	0,0873	2,6546	0,0959	2,7049	0,1025	2,7500	0,0733	2,1183
	Mínimo	0,0202	0,5885	0,0234	0,6646	0,0241	0,6029	0,0139	0,3376

Nota: DP equivale a desvio-padrão; CV equivale a coeficiente de variação

Fonte: elaborada pelos autores.

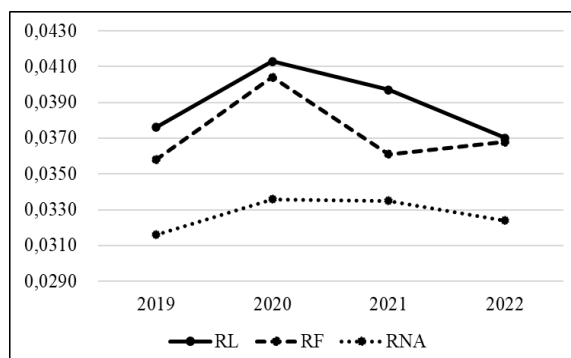


Figura 1a: Evolução do desempenho mediano calculado pelo MAPE para os modelos estimados

Fonte: elaborada pelos autores




Figura 1b: Evolução do desempenho mediano calculado pelo RMSE para os modelos estimados

Verifica-se que os modelos baseados em RNA apresentaram resultados superiores aos baseados em RL e em RF, considerando ambas as métricas. Ao se analisar o MAPE (Figura 1a), destaca-se que o desempenho mediano dos modelos de RL melhorou substancialmente a

partir de 2020, ficando próximo aos dos algoritmos de IA. Já no caso da análise do RMSE (Figura 1b), observou-se que todos os modelos apresentaram melhorias na capacidade de previsão a partir de 2021, com uma superioridade clara dos baseados em RNA.

Para verificar se os modelos de IA apresentaram um desempenho efetivamente superior aos da RL, empregou-se o teste de Mann-Whitney, tal como apresentado na seção anterior deste trabalho. Nesse caso, observou-se que, em nenhum período, os modelos estimados com base na RL apresentaram diferenças estatisticamente significantes em relação aos estimados com base no algoritmo de RF. Porém, em 2019 e 2020, o desempenho superior da RNA foi confirmado como estatisticamente significativo em relação aos estimados com base em RL nas duas métricas empregadas para avaliação.

Desse modo, observa-se que o desempenho dos modelos estimados a partir dos algoritmos de IA não foi consistentemente superior ao dos modelos baseados em RL. Apenas os modelos estimados com base em RNA conseguiram superar os estimados com base naquela métrica tradicional, mas não em todos os períodos. Dessa forma, H3 é corroborada apenas de forma parcial, não confirmando a hipótese conforme esperado com base em Qian e Rasheed (2007) e Shynkevich *et al.* (2017) e Cao *et al.* (2019).

4.3. DESEMPENHO DOS MODELOS CONSIDERANDO PAÍSES DESENVOLVIDOS E EMERGENTES

Na Tabela 4, demonstram-se as estatísticas de desempenho dos modelos estimados com RL e com base em algoritmos de IA ao longo dos anos, considerando a segregação em países emergentes (África do Sul, Arábia Saudita, Argentina, Brasil, China, Coreia do Sul, Índia, Indonésia, México, Rússia e Turquia) e desenvolvidos (Alemanha, Austrália, Canadá, Estados Unidos, França, Itália, Japão, Reino Unido). Salienta-se que este último grupo engloba também todos os membros do G7. Em complemento, nas figuras 2a e 2b, são demonstradas, respectivamente, as medianas do MAPE e do RMSE dos modelos baseados em RL e em algoritmos de IA.

Pela análise do MAPE (Figura 2a), os valores medianos de desempenho dos modelos baseados em RL, estimados para os países desenvolvidos, foram superiores àqueles estimados para os países emergentes entre os anos de 2019 e 2021. Sendo que para os modelos baseados em RF estes valores foram superiores nos anos de 2020 a 2022. Nos modelos baseados em RNA os valores dos países desenvolvidos foram inferiores apenas no ano de 2021. No caso do RMSE (Figura 2b), também há superioridade do desempenho mediano para os países desenvolvidos em relação aos países emergentes, nos resultados provenientes do RL nos anos de 2019 a 2021. Já para os modelos estimados em RF os valores medianos estimados para os países desenvolvidos foram superiores àqueles estimados para os países emergentes no ano de 2022. Os valores medianos de desempenho dos modelos baseados em RNA foram superiores nos anos de 2021 e 2022.

No intuito de verificar se os modelos estimados para os países desenvolvidos apresentaram um desempenho estatisticamente superior aos estimados para os países emergentes, empregou-se o teste de Mann-Whitney. Nesse caso, em nenhum dos anos analisados, verificaram-se coeficientes estatisticamente significantes no que se refere a modelos estimados para países desenvolvidos em relação aos emergentes, independentemente da métrica empregada para mensurar o desempenho. Assim, não é possível corroborar H4, desenvolvida com base nas premissas de maior eficiência de mercado e qualidade da informação contábil dos mercados dos países desenvolvidos em relação aos emergentes destacadas por estudos como Sánchez-Granero *et al.* (2020), Viana Jr. *et al.* (2023) e Al-Enzy *et al.* (2023).

Tabela 4: Estatísticas de desempenho dos modelos estimados considerando a segregação em países desenvolvidos

	Países	Desenvolvidos											
		Medida/ Ano	MAPE /2019	RMSE /2019	MAPE /2020	RMSE /2020	MAPE /2021	RMSE /2021	MAPE /2022				
Modelos baseados em RL	Média	0,0381	0,9564	0,0411	1,0103	0,0386	0,9831	0,0384	0,9270	0,0458	1,2549	0,0447	1,0000
	DP	0,0050	0,0904	0,0043	0,1027	0,0034	0,1321	0,0054	0,1372	0,0239	0,6452	0,0214	0,0000
	CV	0,1326	0,0945	0,1042	0,1017	0,0877	0,1344	0,1417	0,1480	0,5219	0,5141	0,4790	0,0000
	Mediana	0,0372	0,9450	0,0412	1,0408	0,0396	0,9620	0,0384	0,9060	0,0404	1,1352	0,0430	1,0000
	Máximo	0,0479	1,0800	0,0493	1,1369	0,0428	1,1883	0,0489	1,1728	0,0995	2,7547	0,1047	2,0000
	Mínimo	0,0316	0,8214	0,0351	0,8065	0,0321	0,7896	0,0305	0,7364	0,0205	0,5905	0,0223	0,0000
Modelos baseados em RF	Média	0,0381	0,9739	0,0396	1,0131	0,0356	0,9155	0,0364	0,9071	0,0395	1,0718	0,0443	1,0000
	DP	0,0063	0,1562	0,0052	0,1451	0,0045	0,1069	0,0049	0,1321	0,0188	0,5256	0,0196	0,0000
	CV	0,1645	0,1604	0,1315	0,1432	0,1271	0,1168	0,1355	0,1456	0,4767	0,4904	0,4421	0,0000
	Mediana	0,0395	1,0229	0,0403	1,0103	0,0360	0,9521	0,0356	0,9100	0,0331	0,8772	0,0435	0,0000
	Máximo	0,0456	1,1627	0,0474	1,2232	0,0419	1,0304	0,0452	1,1775	0,0903	2,5195	0,1001	2,0000
	Mínimo	0,0262	0,6694	0,0290	0,7478	0,0268	0,6922	0,0274	0,6771	0,0197	0,5449	0,0267	0,0000
Modelos baseados em RNA	Média	0,0336	0,8431	0,0364	0,9036	0,0342	0,8584	0,0335	0,8383	0,0369	1,0075	0,0402	1,0000
	DP	0,0078	0,1697	0,0070	0,1536	0,0057	0,1221	0,0042	0,1138	0,0183	0,5620	0,0199	0,0000
	CV	0,2334	0,2013	0,1939	0,1700	0,1678	0,1423	0,1247	0,1358	0,4956	0,5578	0,4959	0,0000
	Mediana	0,0339	0,8274	0,0354	0,8567	0,0335	0,8358	0,0324	0,8029	0,0295	0,7982	0,0336	0,0000
	Máximo	0,0490	1,1307	0,0518	1,1932	0,0462	1,1010	0,0424	1,1029	0,0873	2,6546	0,0959	2,0000
	Mínimo	0,0240	0,6096	0,0275	0,7086	0,0273	0,7246	0,0291	0,7424	0,0202	0,5885	0,0248	0,0000

Fonte: elaborada pelos autores.




Figura 2a: Evolução do desempenho mediano calculado pelo MAPE para os modelos estimados por bloco de países.

Fonte: elaborada pelos autores




Figura 2b: Evolução do desempenho mediano calculado pelo RMSE para os modelos estimados por bloco de países.

5. CONCLUSÕES

O estudo apresentado neste artigo visou prever o MVA® de empresas dos países do G20 com base em algoritmos de IA, a partir de variáveis contábeis. Para tanto, foram empregados dados de 16.452 companhias abertas dos países membros desse grupo entre os anos de 2019 e 2022, estimando modelos de previsão com base em RL e em dois algoritmos de IA: RF e RNA.

Em geral, verificou-se que as variáveis contábeis foram relevantes para explicar o valor corporativo mesmo em períodos de crise. Todos os modelos foram considerados significantes e com alto poder explicativo do MVA®. Em alguns períodos, os modelos baseados em RNA apresentaram resultados estatisticamente superiores aos baseados em RL, considerando ambas as métricas empregadas para mensurar o desempenho. Por outro lado, observou-se que, em nenhum período, os modelos estimados com base na RF apresentaram diferenças estatisticamente significantes em relação aos estimados com base na RL. Salienta-se, ainda, que não foram observadas diferenças estatisticamente significantes entre os modelos estimados para empresas de países desenvolvidos em relação àqueles estimados para empresas de países emergentes.

Diante do exposto, a pesquisa apresentada neste artigo contribui de forma relevante para a literatura sobre Contabilidade e Finanças sob diferentes aspectos: (a) destacou-se a relevância das variáveis contábeis para previsão de valor corporativo, mesmo em períodos de crise; (b) evidenciou-se a importância de emprego de algoritmos de IA para análise desse fenômeno em estudos da área; e (c) os resultados foram corroborados considerando milhares de empresas provenientes dos países mais industrializados do mundo.

Contudo, a pesquisa ora desenvolvida também apresentou algumas limitações. Primeiramente, ressalta-se que as métricas empregadas para se mensurar o valor e operacionalizar as variáveis contábeis são inerentemente limitadas. Além disso, empregou-se uma abordagem transversal para análise, devido às limitações inerentes aos algoritmos usados. Assim, sugere-se para estudos futuros: (i) explorar mais variáveis explicativas tais como indicadores setoriais, características de governança corporativa, entre outros; (ii) avaliar a aplicação de métricas alternativas, tanto de valor das empresas quanto das variáveis contábeis; e (iii) empregar algoritmos que possibilitem a análise longitudinal dos dados.

6. REFERÊNCIAS

- ABBASSI, W.; KUMARI, V. & PANDEY, D. K.**, What makes firms vulnerable to the Russia–Ukraine crisis? *The Journal of Risk Finance*, [s. l.], v. 24, ed. 1, 2023, pp. 24-39. DOI 10.1108/JRF-05-2022-0108
- AGUIAR, A. B. D.; PIMENTEL, R. C.; REZENDE, A. J. & CORRAR, L. J.** Análise dos direcionadores de valor em empresas brasileiras. *RAM. Revista de Administração Mackenzie*, v. 12, n. 2, 2011, pp. 90-112.
- AL ANI, M. K.** Earnings quality and foreign investors in gulf cooperation council countries. *Contemporary Management Research*, 17(3), 2021, pp. 223-270.
- AL-ENZY, N. S. K., MONEM, R., & NAHAR, S.** IFRS experience and earnings quality in the GCC region. *International Journal of Managerial Finance*, 19(3), 2023, pp. 670-690.
- ANANTHAKUMAR, U. & SARKAR, R.** Application of logistic regression in assessing stock performances. In: 2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech). IEEE, 2017. pp. 1242-1247.
- AVELAR, E. A.; CAMPOS, O. V.; OREFICI, J. B. P.; BORGES, S. L. & SOUZA, A. A.** Inteligência artificial e previsão de preços de ativos financeiros: uma revisão sistemática. *Sistemas & Gestão*, [S. l.], v. 17, n. 3, 2022, pp. 271-285.



- BELFIORE, P.**, Estatística Aplicada a Administração, Contabilidade e Economia. 1ª Edição. Rio de Janeiro: Elsevier, 2015.
- BELHAJ, S. & MAMOGLI, C.** NeuroEvolution of Augmenting Topologies for predicting financial distress: A multicriteria decision analysis. Wiley Online Library, [s. l.], v. 26, 2019, pp. 320-328. DOI 10.1002/mcda.1669
- BORGES, M. R.** Efficient market hypothesis in European stock markets. The European Journal of Finance, 16(7), 2010, pp. 711-726.
- BOUGIAS, A.; EPISCOPOS, A. & LELEDAKIS, G. N.** Valuation of European firms during the Russia-Ukraine war. Economics Letters, [s. l.], v. 218, 2022. DOI 10.1016/j.econlet.2022.110750
- BRAGA, A. P.; CARVALHO, A. C. P. L. F. & LUDERMIR, T. B.** Redes neurais artificiais: teoria e aplicações. 2ª Edição. Rio de Janeiro: LTC, 2007.
- CAO, H.; YING LI, T. L. & ZHANG, H.** Stock Price Pattern Prediction Based on Complex Network and Machine Learning. Complexity. 2019, p 12. DOI 10.1155/2019/4132485
- CHANEY, P. K., FACCIIO, M., & PARSLEY, D.** The quality of accounting information in politically connected firms. Journal of Accounting and Economics, 51(1-2), 2011, pp. 58-76.
- FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A. & CARVALHO, A. C. P. L. F.** Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina, 2ª Edição. Rio de Janeiro: LTC, 2021.
- FAMA, E. F.** Efficient capital markets: A review of theory and empirical work. The journal of Finance, 25(2), 1970, pp. 383-417.
- FERREIRA, F. G. D. C.; GANDOMI, A. H. & CARDOSO, R. T. N.** Artificial intelligence applied to stock market trading: a review. IEEE Access, v. 9, 2021, pp. 30898-30917. DOI 10.1109/ACCESS.2021.3058133
- GAVUROVA, B., JENCOVA, S., BACIK, R., MISKUFOVA, M. & LETKOVSKY, S.** Artificial intelligence in predicting the bankruptcy of non-financial corporations. Oeconomia Copernicana, v. 13, n. 4, 2022, pp. 1215-1251. DOI:10.24136/oc.2022.035
- GRUPO DOS VINTE (G20).** Sobre o G20. Membros do G20. <https://www.g20.org/pt/about-g20/>
- GUJARATI, D. N. & PORTER, D. C.** Econometria básica. 5ª Edição. Porto Alegre: AMGH, 2011.
- HUSAIN, T.; SARWANI; SUNARDI, N. & LISDAWATI.** Firm's Value Prediction Based on Profitability Ratios and Dividend Policy. Finance & Economics Review, v. 2, n. 2, 2020, pp. 13-26.
- ICHSAN, R. N.; SUPARMIN, S.; YUSUF, M.; ISMAL, R. & SITOMPUL, S.** Determinant of Sharia Bank's Financial Performance during the Covid-19 Pandemic. Budapest International Research and Critics Institute-Journal (BIRCI-Journal), [s. l.], v. 4, n. 1, 2021 pp. 298-309.
- JALLOW, M. A.; ABIODUN, N. L.; WEKE, P. & AIDARA, C. A. T.** Efficiency of Financial Ratios in Predicting Stock Price Trends of Listed Banks at Nairobi Securities Exchange. European Journal of Statistics, v. 2, 2022, 9. DOI 10.28924/ada/stat.2.9
- JAMES, G.; WITTEN, D.; HASTIE, T. & TIBSHIRANI, R.** An introduction to statistical learning: with Applications in R. New York: Springer, 2013.
- KACZMAREK, T.; PEREZ, K.; DEMIR, E. & ZAREMBA, A.** How to survive a pandemic: The corporate resiliency of travel and leisure companies to the COVID-19 outbreak. Tourism Management, [s. l.], v. 84, 2021. DOI 10.1016/j.tourman.2020.104281
- LIAPIS, A.; ARTSIDAKIS, S. & GALANOS, C.** Forecasting Methods of Key Ratios and Their Impact in Company's Value. Journal of Risk and Financial Management, v. 16, n. 3, 2023, 140. DOI 10.3390/jrfm16030140
- MARQUES, T. DE Á., GUIMARÃES, T. M. & PEIXOTO, F. M.** A Concentração Acionária no Brasil: Análise dos Impactos no Desempenho, Valor e Risco da Empresas. RAM. Revista de Administração Mackenzi, [s. l.], 2015. DOI 10.1590/1678-69712015/administracao.v16n4p100-133
- MISHRA, S. & MOHANTY, P.** Corporate governance as a value driver for firm performance: evidence from India. Corporate Governance. v. 14, n. 2, 2014, pp. 265-280. DOI:10.1108/CG-12-2012-0089
- MULYANINGSIH, T.; CAHYADIN, M. & SARMIDI, T.** Firms' Financial Distress during the COVID-19 Pandemic and Fiscal Incentives. Economic Research Institute for ASEAN and East Asia, [s. l.], n. 07, 2021, p. 7.
- NAZLIOGLU, S., PAZARCI, S., KAR, A., & VAROL, O.** Efficient market hypothesis in emerging stock markets: gradual shifts and common factors in panel data. Applied Economics Letters, 2023, pp. 1-7.

QIAN, B. & RASHEED, K. Stock market prediction with multiple classifiers. *Applied Intelligence*, v. 26, n. 1, 2007, pp. 25–33. DOI 10.1007/s10489-006-0001-7

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE, J. & LAMB, R. *Administração financeira*. 10ª Edição. São Paulo: AMGH Editora, 2015.

SADORSKY, P. A random forests approach to predicting clean energy stock prices. *Journal of Risk and Financial Management*, v. 14, n. 2, 2021, p. 48. DOI 10.3390/jrfm14020048

SÁNCHEZ-GRANERO, M. A., BALLADARES, K. A., RAMOS-REQUENA, J. P., & TRINIDAD-SEGOVIA, J. E. Testing the efficient market hypothesis in Latin American stock markets. *Physica A: Statistical Mechanics and its Applications*, 2020, pp. 540, 123082.

SHYNKEVICH, Y.; MCGINNITY, T.M.; COLEMAN, S. A. & BELATRECHE, A. Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*. v. 264, 2017, pp. 71–88. DOI 10.1016/j.neucom.2016.11.095

STEWART, G. B. *Em busca do valor: o guia de EVA para estrategistas*. Porto Alegre: Bookman, 2005.

VASCONCELOS, L. N. C. & CALLADO, A. L. C. Comparação entre as Métricas de Desempenho Financeiro e a Maximização do Valor nas Firms Abertas Brasileiras. *Sociedade, Contabilidade e Gestão*, v. 14, n. 1, 2019, pp. 32-53.

VIANA JR, D. B. C., LOURENÇO, I., BLACK, E. L., & MARTINS, O. S. Macroeconomic instability, institutions, and earnings management: An analysis in developed and emerging market countries. *Journal of International Accounting, Auditing and Taxation*, 2023, pp. 51, 100544.